

引文格式:张 海,马小平,苏三庆,等.基于机器学习的钢筋混凝土矩形柱破坏模式预测研究[J].建筑科学与工程学报,2025,42(2):48-57.  
ZHANG Hai, MA Xiaoping, SU Sanqing, et al. Research on failure mode prediction of rectangular reinforced concrete columns based on machine learning[J]. Journal of Architecture and Civil Engineering, 2025, 42(2): 48-57.

DOI:10.19815/j.jace.2023.08007

# 基于机器学习的钢筋混凝土矩形柱破坏模式预测研究

张 海<sup>1,2</sup>, 马小平<sup>1,2</sup>, 苏三庆<sup>3</sup>, 王 威<sup>3</sup>, 蔡玉军<sup>1,2</sup>

- 中铁第一勘察设计院集团有限公司 极端环境岩土和隧道工程智能建养全国重点实验室, 陕西 西安 710043;
- 中铁第一勘察设计院集团有限公司 建筑与规划设计研究院/TOD研发中心, 陕西 西安 710043;
- 西安建筑科技大学 土木工程学院, 陕西 西安 710055)

**摘要:**针对传统分析方法识别效果差、数据依赖性强等问题,以既有试验数据为基础,建立矩形截面钢筋混凝土柱的数据库,应用K邻近、随机森林、支持向量机、梯度提升决策树、深度神经网络等机器学习算法,实现矩形柱破坏模式的有效识别与预测。借助机器学习强大的自学习、自适应能力,精准预测钢筋混凝土矩形柱的破坏模式,并为震后结构的维修加固与损伤评估提供依据。结果表明:机器学习技术对弯曲破坏均有良好的识别效果,随机森林和梯度提升决策树算法的准确率和回归率均达到100%,可用于矩形柱弯曲破坏模式的精准预测;机器学习技术对于剪切破坏的识别效果差别不大,准确率均达66.67%,K邻近、支持向量机、梯度提升决策树的回归率最高,达到100%;对于弯剪破坏模式,随机森林和梯度提升决策树的准确率最高,达到83.33%,支持向量机的预测效果较差。

**关键词:**钢筋混凝土;矩形截面柱;机器学习;破坏模式预测;试验数据

中图分类号:TU393

文献标志码:A

文章编号:1673-2049(2025)02-0048-10

## Research on failure mode prediction of rectangular reinforced concrete columns based on machine learning

ZHANG Hai<sup>1,2</sup>, MA Xiaoping<sup>1,2</sup>, SU Sanqing<sup>3</sup>, WANG Wei<sup>3</sup>, CAI Yujun<sup>1,2</sup>

- State Key Laboratory of Intelligent Construction and Maintenance for Extreme Geotechnical and Tunnel Engineering, China Railway First Survey and Design Institute Group Co., Ltd., Xi'an 710043, Shaanxi, China;
- Research Institute of Architectural & Planning Design/Research Center of Transit Oriented Development, China Railway First Survey and Design Institute Group Co., Ltd., Xi'an 710043, Shaanxi, China;
- School of Civil Engineering, Xi'an University of Architecture & Technology, Xi'an 710055, Shaanxi, China)

**Abstract:** Aiming at the problems of poor recognition effect and strong data dependence in traditional analysis methods, a database of rectangular reinforced concrete columns was established based on existing test data. The machine learning algorithms such as K-nearest neighbor, random forest, support vector machine, gradient boosting decision tree and deep neural

收稿日期:2023-08-04

投稿网址:<http://jace.chd.edu.cn>

基金项目:中铁第一勘察设计院集团有限公司科研开发项目(2022KY51ZD(ZNJC)-03, 2022KY54ZD(ZNXT)-05);

中国施工企业管理协会青年创新项目(2023-B-009);中国铁路西安局集团有限公司科学技术研究开发计划项目(Y2023034)

作者简介:张 海(1967-),男,正高级工程师,E-mail:1911681566@qq.com。

通信作者:马小平(1991-),男,工学博士,高级工程师,E-mail:maxiaopin@live.xauat.edu.cn。

network were applied to realize the effective recognition and prediction of failure modes for rectangular columns. By leveraging the powerful self-learning and self-adaptive ability of machine learning, the failure mode of rectangular reinforced concrete columns was accurately predicted, providing a basis for for the maintenance, reinforcement and damage assessment of post-earthquake structures. The results show that machine learning has a good recognition effect on bending failure. The accuracy and regression rate of random forest and gradient boosting decision tree are both up to 100%, and they can be used to accurately predict the bending failure mode of rectangular columns. The recognition effect of machine learning technology on shear failure is not significantly different, with an accuracy rate of 66.67%. The regression rates of the K-nearest neighbor, support vector machine, and gradient boosting decision tree are the highest, reaching 100%. For bending-shear failure mode, the accuracy of random forest and gradient boosting decision tree is the highest, reaching 83.33%, while the prediction effect of the support vector machine is poor.

**Key words:** reinforced concrete; rectangular column; machine learning; failure mode prediction; experimental data

**Author resumes:** ZHANG Hai(1967-), male, senior engineer, E-mail: 1911681566@qq.com; MA Xiaoping(1991-), male, PhD, senior engineer, E-mail: maxiaopin@live.xauat.edu.cn.

## 0 引 言

钢筋混凝土(RC)柱是提供结构竖向承载力 and 横向抗侧刚度的关键构件,例如铁路桥梁的墩柱、站房结构的框架柱等。因此,震后钢筋混凝土柱破坏模式的识别对灾后结构加固策略的制定和整体损伤程度的评定至关重要。根据构件截面属性、配筋构造、材料属性、约束条件等细节的不同,RC柱表现出 3 种破坏模式:弯曲破坏、剪切破坏、弯剪破坏。弯曲破坏的 RC 柱具有较大的变形能力,柱的轴向承载能力无显著损失,整体呈延性失效;剪切破坏的 RC 柱是一种脆性破坏形态,其表现为在弯曲屈服之前或之后轴向承载能力的突然丧失;弯剪破坏则是介于二者之间,即在剪切破坏之前,由弯曲及轴向荷载导致弯曲屈服或混凝土压碎。

RC 柱破坏模式的预测是土木工程领域的难点问题,特别是剪切破坏模式与弯剪破坏模式的区分。有效识别 RC 柱的破坏模式对结构的震后损伤评估及修复策略的制定至关重要。RC 柱破坏模式的常用预测方法主要分为以下 3 类:

(1)跨高比,其定义为柱计算跨度  $H$  与截面深度  $h$  的比值。当  $H/h < 2$  时,柱发生剪切破坏;当  $H/h \geq 4$  时,柱发生弯曲破坏; $2 \leq H/h < 4$  时,柱将发生弯剪破坏<sup>[1]</sup>。

(2)延性位移,其定义为构件达到最大剪力时的变形与屈服变形的比值。当延性位移  $\mu_{\Delta} \geq 6$  时,

为弯曲破坏;当  $2 < \mu_{\Delta} < 6$  时,为弯剪破坏;当  $\mu_{\Delta} \leq 2$  时,为剪切破坏<sup>[2]</sup>。

(3)经验公式,即基于试验数据回归得到构件设计参数与破坏模式的经验方程,并依据此方程对其他同类构件的破坏模式进行预测<sup>[3-4]</sup>。

研究表明,基于跨高比的破坏模式预测方法存在不足之处,因而后两者方法的应用较为普遍<sup>[5]</sup>。然而,后两种方法均以延性位移为基础,通过横向剪切荷载与延性位移的关系曲线,构建剪切强度模型,进而判断其破坏模式类型。此类预测方式依赖于准确获取 RC 柱的力-位移曲线,而实际数据往往十分有限,易使抗剪强度的计算偏差较大,影响预测结果。另一方面,完全依据试验数据集中的所有设计参数虽然可以对 RC 柱的破坏模式进行初步判断,但容易出现模型过拟合而导致预测结果失准<sup>[6]</sup>。

近年来,以机器学习、深度学习等算法为代表的新一代人工智能技术已成为极具发展前景的手段,并被应用到土木工程领域的规划、设计、建造、维护及防灾等工作中<sup>[7-11]</sup>。机器学习技术(包括深度学习)可通过对既有数据的直接、主动学习,得到数据的潜在模式规律,并可以任意精度逼近联系输入与输出空间的任意连续函数<sup>[12-14]</sup>。Zhang 等<sup>[15]</sup>基于混凝土配合比组分,通过决策树(DT)、线性回归(LR)、人工神经网络(ANN)、支持向量机(SVM)等算法,实现了混凝土抗压强度的预测。Gao 等<sup>[16]</sup>基于混凝土抗压强度、柱轴压力、节点平面内和平面外

几何参数、节点横向配筋、梁柱配筋率等设计参数,通过 K 邻近(KNN)、LR、SVM、ANN、朴素贝叶斯(NB)、DT、随机森林(RF)、自适应算法(Boosting)等,实现了梁柱连接节点破坏模式的准确预测。Hwang 等<sup>[17]</sup>基于地震动参数、框架类型、体系刚度、荷载峰值前后塑性转角、体系有效受弯承载力、屈服后强度比、柱底转动刚度等参数,应用 LR、岭回归(RR)、DT、RF、NB、KNN、Boosting 等算法,对框架结构最大层间位移角与破坏模式进行了有效预测。上述方法表明了基于机器学习算法的 RC 柱破坏模式预测具有潜在可行性。

为了改善已有预测方法的局限性,本文采用机器学习技术对 RC 矩形柱的破坏模式进行预测。针对往复荷载作用下的 RC 矩形柱,依据机器学习算法开展其破坏模式预测的相关研究。为实现上述目标,本文搜集了国外学者提供的 RC 矩形截面柱低周往复试验数据(共计 250 组),并分别应用 KNN、RF、SVM、梯度提升决策树(GBDT)、深度神经网络(DNN)算法对其破坏模式进行预测分析,对比各类方法的准确性,验证所建立的神经网络算法的可行性。

## 1 试验数据

### 1.1 矩形截面柱数据库

依据太平洋地震工程研究中心所提供的结构信息数据库(SPD),基于自编爬虫插件(PEER Spider)自动搜集并整理矩形截面柱的试验数据,形成所需的试验数据库。通过整理分析,得到 250 组矩形截面柱的试验数据,其关键设计变量的分布如图 1 所示。由图 1 可以看出,矩形截面柱数据库中各设计参数的变化范围为:截面宽度  $w$ ,  $80 \text{ mm} \leq w \leq 914.4 \text{ mm}$ ;截面深度  $h$ ,  $80 \text{ mm} \leq h \leq 914 \text{ mm}$ ;混凝土抗压强度  $f_c$ ,  $16 \text{ MPa} \leq f_c \leq 118 \text{ MPa}$ ;纵向钢筋屈服强度  $f_y$ ,  $318 \text{ MPa} \leq f_y \leq 587.1 \text{ MPa}$ ;箍筋屈服强度  $f_{yv}$ ,  $249 \text{ MPa} \leq f_{yv} \leq 1\,424 \text{ MPa}$ ;柱子计算高度  $H$ ,  $80 \text{ mm} \leq H \leq 2\,335 \text{ mm}$ ;轴向压力  $N$ ,  $0 \text{ kN} \leq N \leq 8\,000 \text{ kN}$ ;纵向钢筋配筋率  $\rho$ ,  $0.7\% \leq \rho \leq 6.0\%$ ;箍筋配筋率  $\rho_{sv}$ ,  $0\% \leq \rho_{sv} \leq 6.7\%$ ;跨高比  $H/h$ ,  $1 \leq H/h \leq 7.64$ ;轴压比  $N/(f_c A)$ ,  $0 \leq N/(f_c A) \leq 0.9$ 。

柱子的计算高度  $H$  与试验加载条件有关,对于悬臂柱,为柱子的净高;对于两端固接柱,为柱子净高的  $1/2$ ;对于两端铰接柱,为柱子净高的  $1/2$  减去加载区域高度的  $1/2$ 。纵向钢筋配筋率  $\rho = A_s/A$ ,

其中  $A_s$  为纵向受力钢筋的总截面面积,  $A$  为矩形柱的截面面积。箍筋配筋率  $\rho_{sv} = A_{sv}/sb$ , 其中  $A_{sv}$  为沿同一方向所有箍筋的总截面面积,  $s$  为箍筋间距,  $b$  为矩形柱截面宽度。此外,图 1 展示了破坏模式、加载条件(悬臂、两端固接、两端铰接)的分布情况。

### 1.2 输入变量的确定

根据矩形截面柱数据库中设计变量的相关性(图 2),可以看出矩形柱的截面宽度  $w$  与截面深度  $h$  存在较大的相关性。进一步参考既有文献的研究结果,本文选取并计算了 4 个设计变量,作为钢筋混凝土矩形截面柱破坏模式分类及预测的输入参数。设计变量包括:跨高比  $H/h$ 、轴压比  $N/(f_c A)$ 、纵筋配筋系数  $\rho f_y/f_c$ 、箍筋配筋系数  $\rho_{sv} f_{yv}/f_c$ , 其中  $f_c$  为混凝土抗拉强度,近似取  $0.65(f_c)^{1/2}$ 。

对矩形柱数据库进行可视化处理,得到相关输入变量之间的散点关系,如图 3 所示。从图 3 可以得出以下结论:

(1) 跨高比  $H/h$  较小时,RC 柱易发生剪切破坏,  $H/h$  值较大时,RC 柱易发生弯曲破坏。当  $H/h$  在  $1.72 \sim 3.44$  之间时,RC 柱可能会在弯曲、弯曲-剪切或剪切破坏。因此,仅依据  $H/h$  的值进行破坏模式的识别是不准确的。

(2) 破坏模式之间的边界为复杂非线性,难以依据单一决策面对其进行有效分类识别。

(3) 4 种设计变量之间不存在显著相关性,故可将其作为算法输入变量,用于破坏模式的识别与预测中。

## 2 机器学习算法

本研究将以跨高比、轴压比、纵筋配筋系数、箍筋配筋系数作为输入变量,以弯曲破坏、剪切破坏、弯剪破坏作为输出变量,借助机器学习算法对 RC 矩形柱的破坏模式进行分类或预测。常用的机器学习算法包括:K 邻近、随机森林、支持向量机、梯度提升决策树、深度神经网络。下面将分别对上述几种算法的核心进行简单介绍。

### 2.1 K 邻近

K 近邻是一种简单、常用的机器学习监督学习方法,其主要应用场景包括文本分类、模式识别、图像及空间分类等。原理为:在给定测试样本中,基于某种距离度量找出训练集中与其最靠近的  $k$  个训练样本,然后基于这  $k$  个“邻居”的信息来进行预测。距离的计算方式通常有两种,即欧氏距离  $d_{\text{eucl}}$  [式(1)]和曼哈顿距离  $d_{\text{man}}$  [式(2)]。




图 1 矩形截面柱数据库中设计变量的分布

Fig. 1 Distribution of design variables in database of rectangular section columns

$$d_{\text{eul}} = \left[ \sum_{i=1}^n (x_i - y_i)^2 \right]^{\frac{1}{2}} = \left[ (x - y)(x - y)^T \right]^{\frac{1}{2}} \quad (1)$$

$$d_{\text{man}} = \sum_{i=1}^n |x_i - y_i| \quad (2)$$

式中:  $x$  和  $y$  为所要计算的两个样本变量;  $i$  为样本变量的维度,  $i=1, 2, 3, \dots, n$ 。

因此, KNN 的计算步骤可概括为 3 步: 算距离、找邻居、做分类。KNN 具有简单、易理解、易实现、无需估计参数、无需训练等优点, 但对于样本容量较小的类域, 采用这种算法易产生错误分类。

## 2.2 随机森林

随机森林<sup>[18]</sup>是一种由多个决策树集成森林以预测最终结果的方法, 其中每一棵决策树互不相

关。随机森林算法的原理如图 4 所示。随机森林算法总体分为两步: 第一步是创建决策树, 第二步是根据第一步中决策树的分类结果做出预测。每个决策树的创建步骤为:

(1) 假定总样本数据集为  $\Omega$ , 有放回的随机抽取  $t$  个, 生成该决策树的训练集。

(2) 针对某一样本, 假定有  $m$  个输入变量, 则随机地从  $m$  个特征中选取  $n$  个特征子集。然后将  $n$  个特征中最优的分裂特征用来分裂节点。

最终, 使用每一个随机创建的决策树来预测测试特征的结果, 并计算每个预测目标的票数, 获得票数最高的预测目标即视为随机森林算法的最终预测结果。随机森林算法与单一决策树算法的最大区别是, 在随机森林中查找根节点和分割特征节点的过

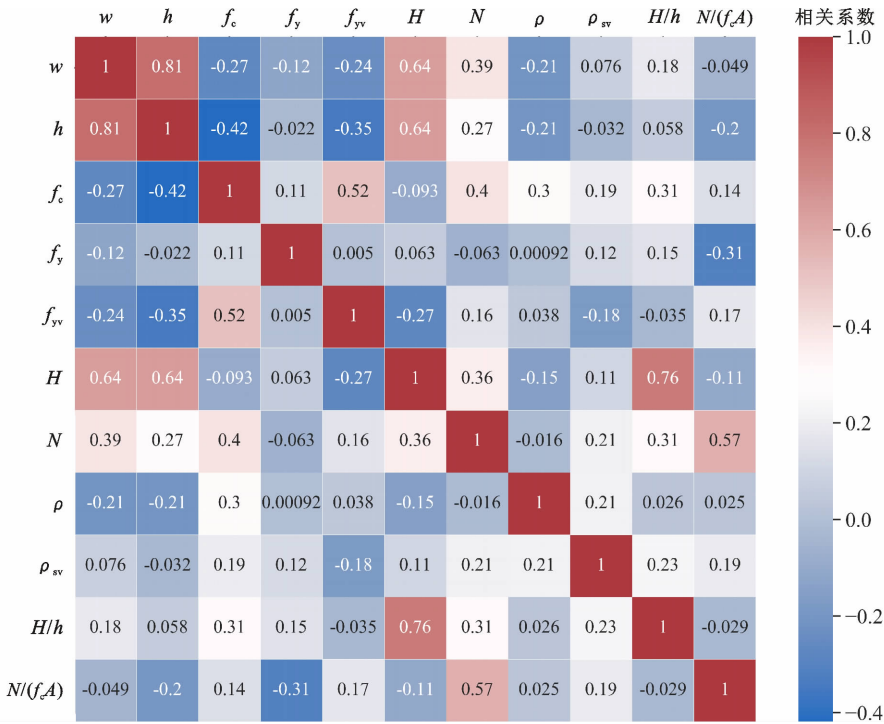


图 2 矩形截面柱数据库中设计变量的相关性热图

Fig. 2 Correlation heatmaps of design variables in database of rectangular section columns

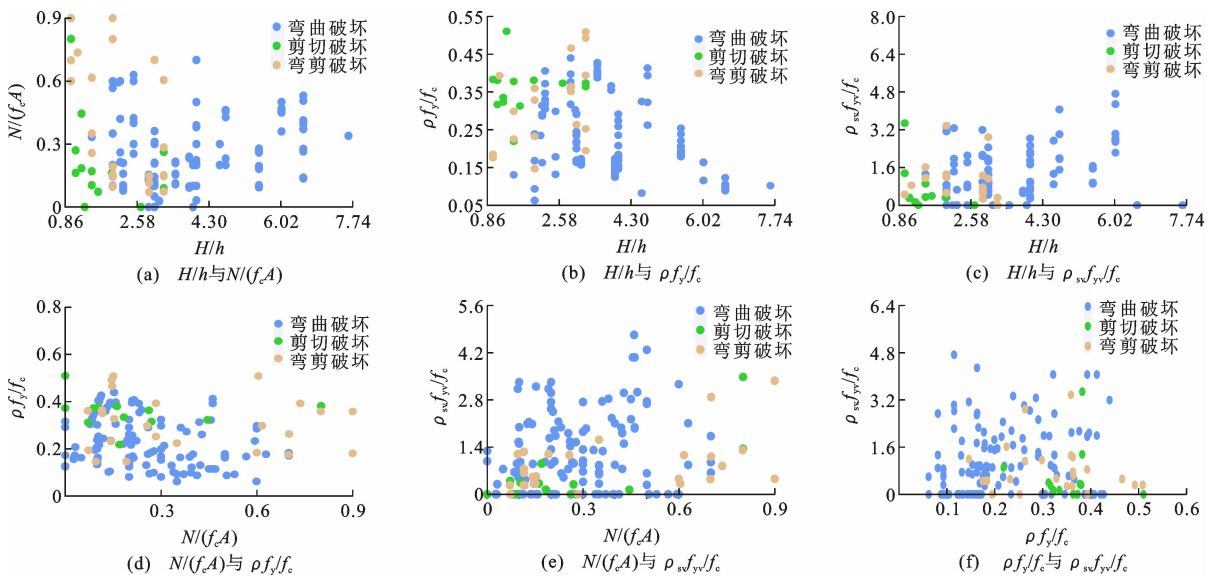


图 3 矩形截面柱数据库中设计变量的散点关系图

Fig. 3 Scatterplot of design variables in database of rectangular section columns

程是随机进行的。因此,RF 算法不仅可处理输入变量多、分类资料集不平衡的情况,而且学习过程速度快、分类准确度高。

### 2.3 支持向量机

支持向量机是一种监督式学习方法,被广泛应用于数据或样本的统计分类及回归分析当中。SVM 的分类原理是找到一个超平面,使其能够尽可能多地将两类数据点正确分开,并且分开的两类数

据点距离超平面最远<sup>[19]</sup>。因此,可以将该问题化为一个求解凸二次规划的问题。SVM 算法是一个典型的二分类模型,而求解能够正确划分训练数据集并且几何间隔最大的分离超平面则是该算法的关键。

SVM 包含两类最基本的算法,即线性可分支持向量机和线性支持向量机。当训练数据线性可分时,可以通过硬间隔最大化,学习一个线性的分类

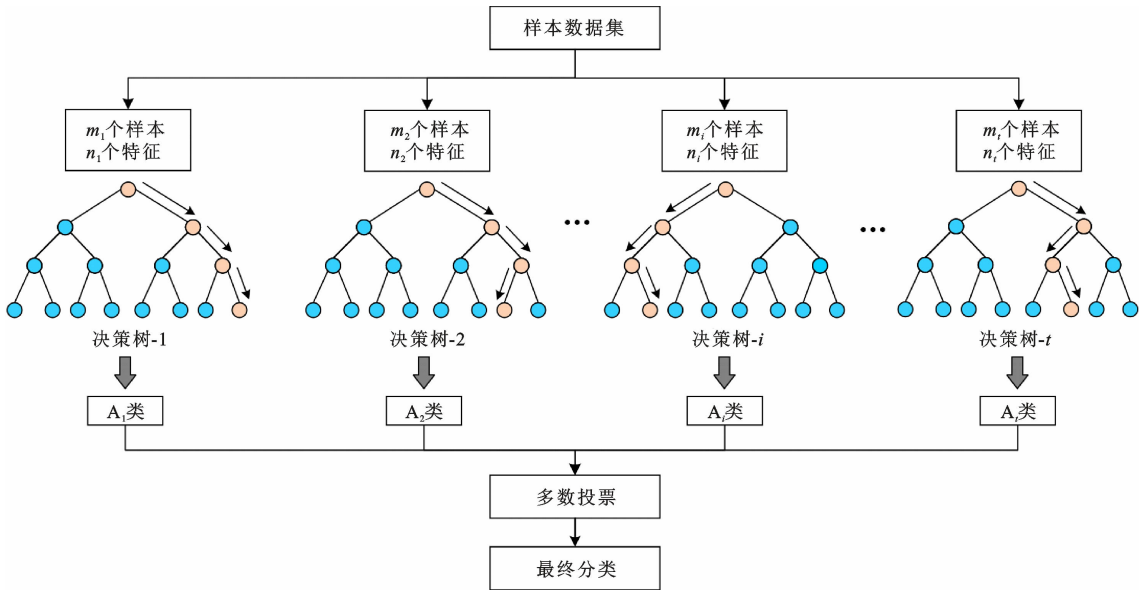


图 4 随机森林原理示意图

Fig. 4 Schematic diagram of random forest principle

器,即线性可分支持向量机,又称为硬间隔支持向量机[图 5(a)];当训练数据近似线性可分时,通过软间隔最大化,也学习一个线性的分类器,即线性支持向量机,又称为软间隔支持向量机[图 5(b)];当训练数据线性不可分时,通过核技巧及软间隔最大化,学习非线性支持向量机[图 5(c)].




图 5 支持向量机的类型

Fig. 5 Types of support vector machines

SVM 主要用于分类问题,主要的应用场景有字符识别、面部识别、行人检测、文本分类等领域。在机器学习领域,SVM 是有监督的学习模型,通常用来进行模式识别、分类(异常值检测)以及回归分析。

2.4 梯度提升决策树

梯度提升决策树可以理解为梯度提升与决策树的结合,该算法由多棵决策树组成,所有树的结论累加起来做最终答案。GBDT 的基本流程为:

- (1)初始化,即估计损失函数极小化的常数值。
- (2)计算损伤函数的负梯度在当前模型中的值,将其作为残差估计,估计回归树叶节点区域,以拟合残差的近似值。
- (3)利用线性搜索估计叶节点区域的值,使损失

函数极小化。

- (4)更新回归树,输出最终模型。

GBDT 算法计算速度快,对于分布稠密的数据集,其泛化及表达能力均较好,且模型具有较好的解释性和鲁棒性。

2.5 深度神经网络

深度神经网络是一种多层无监督神经网络,其以前一层的输出特征作为后一层的输入进行特征学习,通过逐层特征映射后,将现有空间样本的特征映射到另一个特征空间,以此来学习对现有输入具有更好的特征表达。DNN 具有多个非线性映射的特征变换,可以对高度复杂的函数进行拟合<sup>[20-21]</sup>。

DNN 算法由输入层、隐藏层、输出层三部分组成,如图 6 所示。本研究采用前馈多层感知神经网络,包含 3 个隐藏层,其中隐藏层 1 包含 128 个神经元,隐藏层 2 和隐藏层 3 均包含 256 个神经元。在每个隐藏层中,各神经元使用权重函数连接到下一层中的神经元。隐含层中神经元  $i$  的输出  $h_i$  为

$$h_i = s(\sum_{j=1}^N \omega_{ij}x_j + b_i) \tag{3}$$

式中: $s$  为激活函数; $N$  为输入神经元个数; $\omega_{ij}$  为权重; $x_j$  为输入值; $b_i$  为隐藏神经元的阈值项。

本文采用 ReLU 激活函数引入模型的非线性,如式(4)所示。

$$s(u) = \max(0, u) \tag{4}$$

式中: $u$  为激活函数的输入值; $s(u)$  为输出值。

DNN 算法以训练数据为基础,通过对神经网络

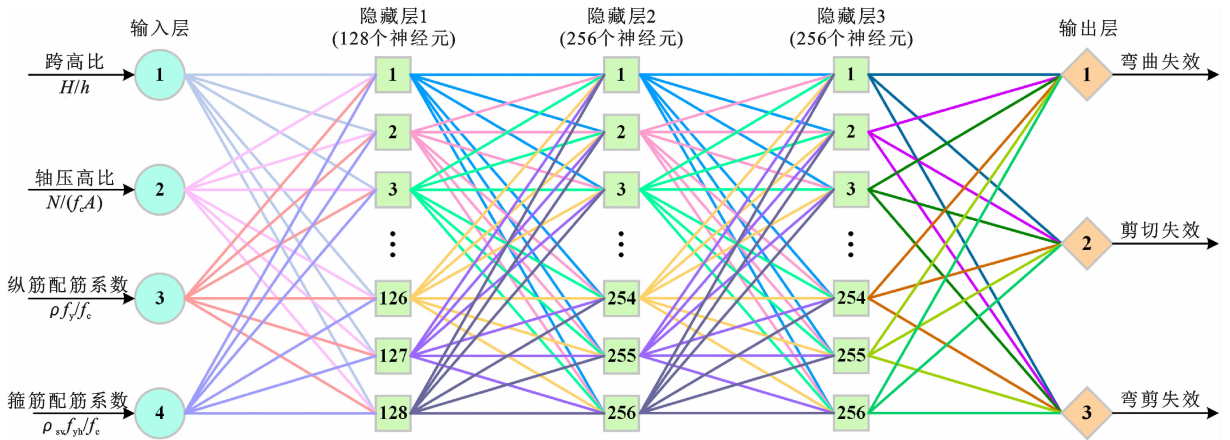


图 6 RC 矩形柱破坏模式预测的深度学习神经网络架构

Fig. 6 Deep neural network architecture for RC rectangular column damage pattern prediction

进行训练,调整连接神经元之间的权值,使预测破坏模式的损失函数达到最小。本研究采用的神经网络优化器为 Adam,该优化器默认的参数设置能实现较好的训练效果。本研究采用的损失函数为均方损失函数,其表达式为

$$F_{\text{loss}}(p_i, q_i) = (p_i - q_i)^2 \quad (5)$$

式中: $p_i$  和  $q_i$  分别为第  $i$  个神经元的损失实际值与预测值。

神经网络内部的迭代损失容差为 0.000 01,即当损失函数计算值小于容差时,认为神经网络训练达到预期。

### 3 不同机器学习算法的预测效果对比

为了有效识别并预测 RC 矩形柱的破坏模式,将整个数据集随机划分为训练集和测试集,其中训练集占总体数据的 75%,测试集占 25%。训练集用于构建预测模型,测试集用于评估模型的性能。为了保证一致性,不同的机器学习方法使用相同的训练集和测试集。通过计算,得到不同算法预测结果与实际结果的对比,如图 7 所示。由图 7 可知,不同机器学习算法对于 RC 柱破坏模式的预测效果差异较大。整体而言,各类算法对于弯曲破坏的预测结果基本准确,但在弯-剪和剪切破坏上却存在误差。KNN 算法对于弯剪破坏和剪切破坏的预测出现 3 次偏差,RFC、GBDT、DNN 则较少,仅出现 2 次,SVM 算法效果最差,其对于弯剪破坏的预测全部失准。SVM 算法对于弯剪破坏预测效果不理想,这除了与算法本身所使用的向量机类型有关外,还与数据量密切相关。进一步基于混淆矩阵对机器学习模型的性能进行评估。混淆矩阵是测试集的实际破坏模式与预测破坏模式的矩阵表。在混淆矩阵中,对

角元素表示机器学习算法正确分类并识别了破坏模式,非对角元素则表示没有正确预测的测试点。图 8 给出了各类机器学习算法中测试集的混淆矩阵。混淆矩阵由三行三列组成,对应 3 种破坏模式。从图 8(a)可以看出,KNN 算法正确预测了 54 种弯曲破坏模式、2 种剪切破坏模式和 4 种弯剪破坏模式。混淆矩阵的准确率和召回率可以评价混淆矩阵的效率。准确率是每种破坏模式成功预测时的百分比。召回率是指在测试集中,实际数据中成功预测破坏模式的占比。准确率和召回率越高,说明实际破坏模式的识别效果越好。以图 8(a)中第一行为例,54 个试件全部预测成功,即 KNN 算法成功预测弯曲破坏模式时的准确率为 100%。同理,以 66.67% 的准确率成功预测剪切破坏模式,以 66.67% 的准确率成功预测弯剪破坏模式。以图 8(a)中第一列为例,56 个实际弯曲破坏模式中有 54 个试件被成功预测,即在实际结果中,弯曲破坏模式预测成功的概率为 96.42%。

此外,混淆矩阵对角阵中反映了每种破坏模式成功预测的个数。在图 8(a)中,对角线元素中数据 52、2、4 分别对应于整个数据集中的弯曲破坏、剪切破坏和弯剪破坏,故其整体模型的准确性为  $(52 + 2 + 4) / 63 \approx 92\%$ 。因此,KNN 算法成功预测了测试集中 92% 的破坏模式。通过分析图 7 和图 8 可得:

(1) 所有机器学习算法都可准确预测弯曲破坏模式,但对于弯剪破坏和剪切破坏,相较于其他算法,RFC 和 GBDT 的预测效果较好,其测试集的整体预测精度可达 96.8%。

(2) 对于弯曲破坏模式,RFC 和 DNN 算法的准确率和召回率都达到 100%,表明 RFC、DNN 可用于 RC 矩形柱弯曲破坏模式的准确预测。此外,

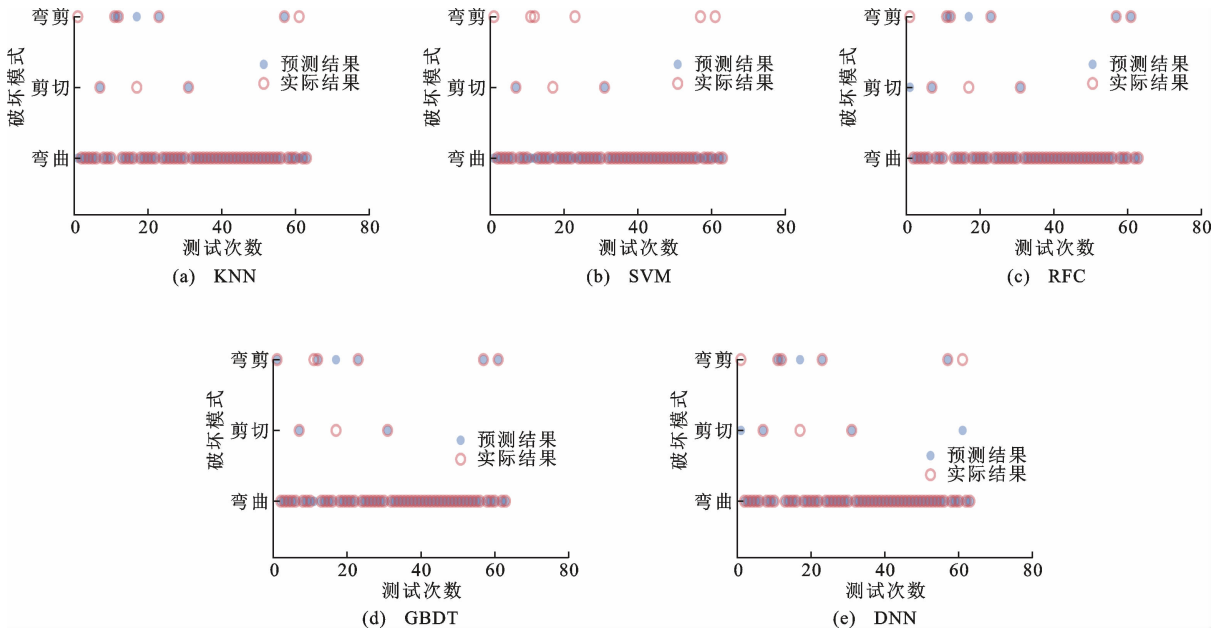


图 7 不同机器学习算法对 RC 矩形柱破坏模式的预测结果

Fig. 7 Prediction results of RC rectangular column damage patterns by different machine learning algorithms

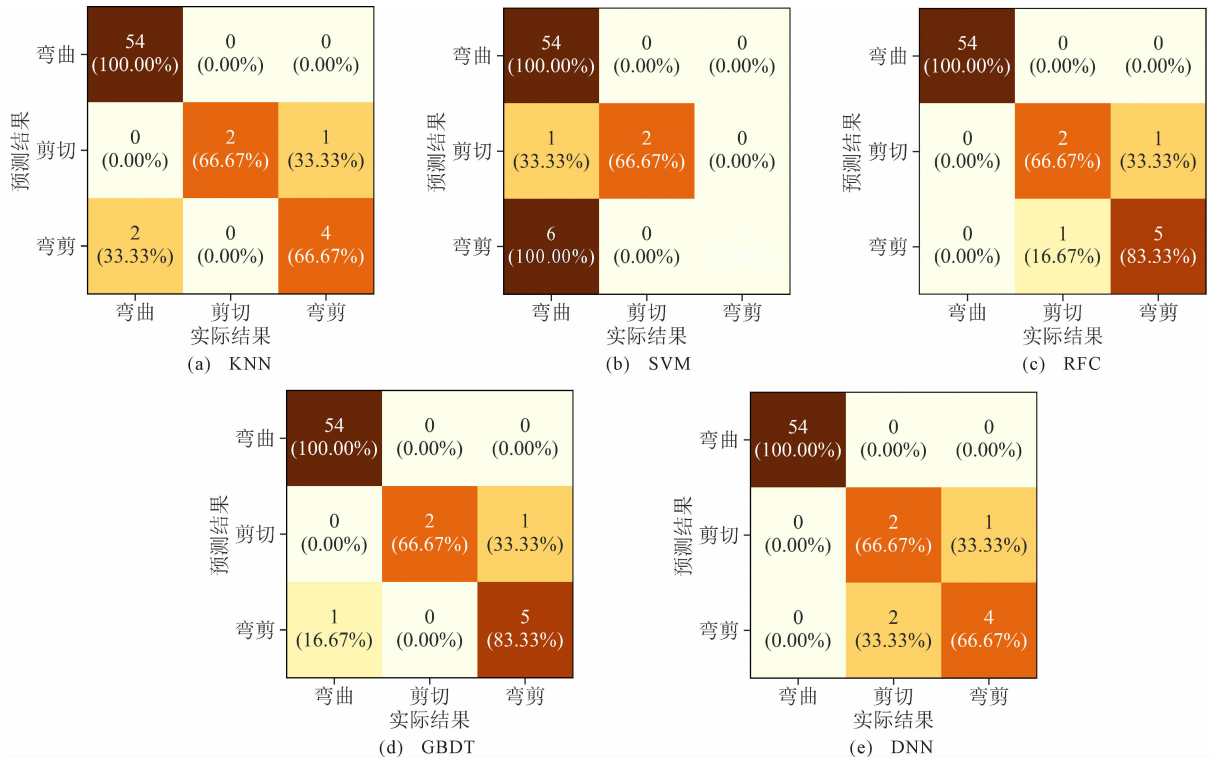


图 8 不同机器学习算法对 RC 矩形柱破坏模式预测的性能评估

Fig. 8 Performance evaluation of different machine learning algorithms for RC rectangular column damage pattern prediction

SVM 的回归率最低。

(3)对于剪切破坏模式,5 种算法的准确率都达到 66.67%,KNN、SVM、GBDT 的回归率达到 100%,RFC 的回归率为 66.67%,DNN 的回归率为 50%。整体而言,对于剪切破坏模式的预测,机器学习算法的预测水准相差不多。

(4)对于弯剪破坏模式,RFC 和 GBDT 的准确率最高,达到 83.33%,KNN 和 DNN 的准确率次之,为 66.67%,而 SVM 无法用于弯剪破坏模式的预测。除 SVM 之外,各类算法的回归率均达到 80%以上。

RC 矩形柱的剪切破坏是典型的脆性破坏模式,而深度学习算法中 RFC 和 GBDT 在识别及预

测此类破坏模式时具有良好的准确率和召回率。此外,本研究所建立的 RC 矩形柱数据库中,弯剪破坏和剪切破坏的试件占总量的 14.4% 和 7.2%,整体占比较小。因此,试验数据库中各类破坏模式对应的试件数量仍然是影响机器学习算法训练效果的关键。

## 4 结 语

(1)对于弯曲破坏模式,所有机器学习算法均具有良好的识别效果。RFC 和 GBDT 算法的准确率和召回率都达到 100%,表明其可用于 RC 矩形柱弯曲破坏模式的精准预测。

(2)对于剪切破坏模式,所有机器学习算法的识别效果差别不大,准确率均达到 66.67%,KNN、SVM、GBDT 的召回率达到 100%,RFC 的召回率为 66.67%,DNN 的召回率为 50%。

(3)对于弯剪破坏模式,RFC 和 GBDT 的准确率最高,达到 83.33%,KNN 和 DNN 的准确率次之,为 66.67%,而 SVM 无法用于弯剪破坏模式的预测。除 SVM 之外,各类算法的召回率均达到 80%以上。

(4)震后钢筋混凝土构件破坏模式的准确识别是确定结构后期加固策略和评估整体损伤程度的关键。本文所开展的研究可为 RC 矩形柱破坏模式的预测提供一定参考。然而,由于试验数据库中剪切破坏和弯剪破坏构件的数量占比仍然较少,故缺乏对于此类破坏模式的训练数据,因而其训练效果不显著。在今后的研究中,应进一步搜集相关的试验数据,丰富试验数据库,优化机器学习算法的训练样本,以提高预测精度。

### 参考文献:

### References:

[1] QI Y L, HAN X L, JI J. Failure mode classification of reinforced concrete column using Fisher method [J]. Journal of Central South University, 2013, 20(10): 2863-2869.

[2] GHEE A B, PRIESTLEY M J N, PAULAY T. Seismic shear strength of circular reinforced concrete columns[J]. ACI Structural Journal, 1989, 86(1): 45-59.

[3] KOWALSKY M J, PRIESTLEY M J N. Improved analytical model for shear strength of circular reinforced concrete columns in seismic regions[J]. ACI Structural Journal, 2000, 97(3): 388-396.

[4] SEZEN H, MOEHLE J P. Shear strength model for lightly reinforced concrete columns[J]. Journal of Structural Engineering, 2004, 130(11): 1692-1703.

[5] MA Y, GONG J X. Probability identification of seismic failure modes of reinforced concrete columns based on experimental observations[J]. Journal of Earthquake Engineering, 2018, 22(10): 1881-1899.

[6] MANGALATHU S, JEON J S. Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using machine learning techniques [J]. Engineering Structures, 2018, 160: 85-94.

[7] 樊健生,王琛,宋凌寒.土木工程智能计算分析研究进展与应用[J].建筑结构学报,2022,43(9):1-22. FAN Jiansheng, WANG Chen, SONG Linghan. Research and application of intelligent computation in civil engineering[J]. Journal of Building Structures, 2022, 43(9): 1-22.

[8] 鲍跃全,李惠.人工智能时代的土木工程[J].土木工程学报,2019,52(5):1-11. BAO Yuequan, LI Hui. Artificial intelligence for civil engineering [J]. China Civil Engineering Journal, 2019, 52(5): 1-11.

[9] 马宏伟,林逸洲,聂振华.利用少量传感器信息与人工智能的桥梁结构安全监测新方法[J].建筑科学与工程学报,2018,35(5):9-23. MA Hongwei, LIN Yizhou, NIE Zhenhua. New method of structural health monitoring based on small amount of sensor information and artificial intelligence[J]. Journal of Architecture and Civil Engineering, 2018, 35(5): 9-23.

[10] 王琛,樊健生.具有历史依赖效应的材料及结构响应预测通用深度学习模型 MechPerformer[J].建筑结构学报,2022,43(8):209-219. WANG Chen, FAN Jiansheng. A general deep learning model MechPerformer for history-dependent response prediction in structural engineering[J]. Journal of Building Structures, 2022, 43(8): 209-219.

[11] WANG J J, WANG C, FAN J S, et al. A deep learning framework for constitutive modeling based on temporal convolutional network [J]. Journal of Computational Physics, 2022, 449: 110784.

[12] 徐阳,金晓威,李惠.土木工程智能科学与技术研究现状及展望[J].建筑结构学报,2022,43(9):23-35. XU Yang, JIN Xiaowei, LI Hui. State-of-the-art and prospect of intelligent science and technology in civil engineering [J]. Journal of Building Structures,

- 2022, 43(9): 23-35.
- [13] 赵艳男,杜文凤,王英奇,等. 基于 BP 神经网络算法的树状结构智能找形研究[J]. 建筑结构学报, 2022, 43(4): 77-85.  
ZHAO Yannan, DU Wenfeng, WANG Yingqi, et al. Study on intelligent shape finding for tree-like structures based on BP neural network algorithm [J]. Journal of Building Structures, 2022, 43(4): 77-85.
- [14] 王 琛,何有泉,宋凌寒,等. 理论辅助的弹塑性本构关系小样本深度学习[J]. 工程力学, 2023, 40(9): 29-36.  
WANG Chen, HE Youquan, SONG Linghan, et al. A theory-aided few-shot deep learning algorithm for elastoplastic constitutive relationships[J]. Engineering Mechanics, 2023, 40(9): 29-36.
- [15] ZHANG R L, XUE X H. A predictive model for the bond strength of near-surface-mounted FRP bonded to concrete[J]. Composite Structures, 2021, 262: 113618.
- [16] GAO X L, LIN C. Prediction model of the failure mode of beam-column joints using machine learning methods[J]. Engineering Failure Analysis, 2021, 120: 105072.
- [17] HWANG S H, MANGALATHU S, SHIN J, et al. Machine learning-based approaches for seismic demand and collapse of ductile reinforced concrete building frames [J]. Journal of Building Engineering, 2021, 34: 101905.
- [18] 司 炜. 基于随机森林算法的纤维喷射混凝土力学性能及抗渗性研究[J]. 混凝土, 2022(11): 36-40.  
SI Wei. Research on mechanical properties and impermeability of fiber reinforced shotcrete based on random forest algorithm [J]. Concrete, 2022 (11): 36-40.
- [19] 李启明,喻泽成,余 波,等. 钢筋混凝土柱地震破坏模式判别的两阶段支持向量机方法[J]. 工程力学, 2022, 39(2): 148-158.  
LI Qiming, YU Zecheng, YU Bo, et al. Two-stage support vector machine method for failure mode classification of reinforced concrete columns [J]. Engineering Mechanics, 2022, 39(2): 148-158.
- [20] 韩小雷,吴梓楠,杨明灿,等. 基于深度学习的区域 RC 框架结构震损评估方法研究[J]. 建筑结构学报, 2020, 41(增 2): 27-35.  
HAN Xiaolei, WU Zinan, YANG Mingcan, et al. Research on seismic damage assessment of regional RC frame structures based on deep learning [J]. Journal of Building Structures, 2020, 41(S2): 27-35.
- [21] BAO Y Q, CHEN Z C, WEI S Y, et al. The state of the art of data science and engineering in structural health monitoring [J]. Engineering, 2019, 5(2): 234-242.